



MINISTÉRIO DA EDUCAÇÃO  
Universidade Federal de Ouro Preto  
Instituto de Ciências Exatas e Aplicadas  
Especialização em Ciência de Dados



# **Aplicação de redes neurais para a predição do volume de madeira extraído por hora de uma empresa produtora de celulose**

**Bruno Garuzzi Pezzin**

João Monlevade, MG  
2024

Bruno Garuzzi Pezzin

**Aplicação de redes neurais para a predição do volume de madeira extraído por hora de uma empresa produtora de celulose**

Trabalho de conclusão de curso apresentado ao curso de Ciência de Dados do Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto, como parte dos requisitos necessários para a obtenção do título de Especialista em Ciência de Dados.

Orientador: Prof. Dr. Paganini Barcellos de Oliveira  
Coorientador: Prof. Dr. Thiago Augusto de Oliveira Silva

João Monlevade, MG

2024

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

P522a Pezzin, Bruno Garuzzi.

Aplicação de redes neurais para a predição do volume de madeira extraído por hora de uma empresa produtora de celulose. [manuscrito] / Bruno Garuzzi Pezzin. - 2024.

32 f.

Orientador: Prof. Dr. Paganini Barcellos de Oliveira.

Coorientador: Prof. Dr. Thiago Augusto de Oliveira Silva.

Produção Científica (Especialização). Universidade Federal de Ouro Preto. Departamento de Engenharia de Produção.

1. Industria de celulose. 2. Modelos matemáticos. 3. Previsão. 4. Produtividade. 5. Redes neurais (Computação). I. Oliveira, Paganini Barcellos de. II. Silva, Thiago Augusto de Oliveira. III. Universidade Federal de Ouro Preto. IV. Título.

CDU 519.2:004.8

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



## FOLHA DE APROVAÇÃO

**Bruno Garuzzi Pezzin**

### **Aplicação de redes neurais para a predição do volume de madeira extraído por hora de uma empresa produtora de celulose**

Trabalho de conclusão de curso apresentado ao curso de Ciência de Dados da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Especialista em Ciência de Dados

Aprovada em 23 de maio de 2024

#### Membros da banca

Doutor - Paganini Barcellos de Oliveira - Orientador - Universidade Federal de Ouro Preto  
Doutor - Thiago Augusto de Oliveira Silva - Coorientador - Universidade Federal de Ouro Preto  
Doutor - Luiz Carlos Bambirra Torres - Universidade Federal de Ouro Preto  
Doutor - Flávio Marcelo Correa - CENIBRA (Celulose Nipo-Brasileira S.A.)

Paganini Barcellos de Oliveira, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 13/06/2024



Documento assinado eletronicamente por **Paganini Barcellos de Oliveira, PROFESSOR DE MAGISTERIO SUPERIOR**, em 13/06/2024, às 09:46, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0720452** e o código CRC **108BE1B2**.

# Resumo

Este trabalho tem como foco a proposição de redes neurais do tipo *Multi-Layer Perceptron* (MLP) para a predição da produtividade dos equipamentos conhecidos como *Forwarders*, em metros cúbicos por hora ( $m^3/h$ ), nas atividades de colheita florestal de uma produtora de celulose. Inicialmente, foram identificadas algumas das variáveis que influenciam no indicador de desempenho operacional dos equipamentos. Na sequência, a metodologia proposta se deu a partir da coleta e preparação dos dados, a modelagem das redes neurais MLP em função dos ajustes nos hiperparâmetros, e as avaliações de desempenho dos modelos com base nos erros absoluto e quadrático médios. A melhor configuração obtida entre as redes MLP testadas resultou em erro médio absoluto de 4,03 e um erro quadrático médio de 27,05. Esse resultado representa uma redução de 13% no erro de predição dos índices de produtividade dos *Forwarders* em comparação com a metodologia atualmente empregada pela empresa.

**Palavras-chaves:** *Forwarder*. Rede neural perceptron multicamadas. Predição.

# Abstract

This work proposes the use of Multi-Layer Perceptron (MLP) neural networks to predict the productivity of equipment known as Forwarders, in cubic meters per hour ( $m^3/h$ ), in the forest harvesting activities of a pulp manufacturing company. First, some variables that influence the operational performance indicator of the equipment were identified. The proposed methodology continued from data collection and preparation, modeling of MLP neural networks based on adjustments to hyperparameters, and model performance evaluations based on absolute and mean squared errors. The best configuration obtained among the tested MLP networks resulted in a mean absolute error of 4.03 and a mean squared error of 27.05. This result represents a 13% reduction in the prediction error of Forwarders' productivity rates compared to the methodology adopted by the company nowadays.

**Keywords:** Forwarder. Multi-Layer Perceptron neural network. Prediction.

# Lista de ilustrações

Figura 1 – Representação gráfica de uma rede MLP . . . . .	7
Figura 2 – Mosaico das áreas dos projetos . . . . .	8
Figura 3 – Exemplo de planilha de dados utilizada para a construção das curvas de produtividade . . . . .	11
Figura 4 – Exemplo de imagem de um <i>dashboard</i> de produção de colheita adotado pela empresa . . . . .	12
Figura 5 – Simulação operacional de colheita . . . . .	13
Figura 6 – Lista de <i>SharePoints</i> com indicadores alterados . . . . .	14
Figura 7 – Planilha que ilustra os dados de entrada . . . . .	18
Figura 8 – Dados de entrada carregados no ambiente do Google Colab . . . . .	18
Figura 10 – Mapa de calor das correlações entre variáveis . . . . .	21
Figura 11 – Gráfico do histórico de treinamento da rede MLP número 1 da Tabela 2 . . . . .	24
Figura 12 – Gráfico comparativo valores reais × valores preditos . . . . .	25

# Lista de tabelas

Tabela 1 – Melhores configurações para a rede MLP para os dois conjuntos de proporções de treinamento e teste, 70/30 e 80/20, considerando os menores valores de MAE. . . . .	23
Tabela 2 – Cinco melhores resultados dos hiperparâmetros com treino e teste na proporção 80/20 . . . . .	24

# Lista de quadros

Quadro 1 – Caracterização dos conjuntos de dados de entrada do modelo . . . . .	17
Quadro 2 – Dados com variáveis categóricas . . . . .	20
Quadro 3 – Dados pós-alteração para representação numérica . . . . .	20
Quadro 4 – Hiperparâmetros da rede neural que foram calibrados . . . . .	22

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b> . . . . .	<b>1</b>
<b>1.1</b>	<b>Objetivo geral</b> . . . . .	<b>2</b>
1.1.1	Objetivos específicos . . . . .	2
<b>1.2</b>	<b>Justificativa</b> . . . . .	<b>3</b>
<b>1.3</b>	<b>Organização do Trabalho</b> . . . . .	<b>3</b>
<b>2</b>	<b>REVISÃO DA LITERATURA</b> . . . . .	<b>4</b>
<b>2.1</b>	<b>Colheita florestal</b> . . . . .	<b>4</b>
2.1.1	Colheita florestal mecanizada: eficácia e eficiência . . . . .	5
<b>2.2</b>	<b>Uso de inteligência artificial para o planejamento florestal de colheita</b> . . . . .	<b>6</b>
<b>3</b>	<b>DESCRIÇÃO DO PROBLEMA</b> . . . . .	<b>8</b>
<b>3.1</b>	<b>Indicadores de desempenho na colheita florestal</b> . . . . .	<b>9</b>
3.1.1	Indicador de disponibilidade mecânica . . . . .	9
3.1.2	Indicador de eficiência operacional . . . . .	10
3.1.3	Indicador de produtividade . . . . .	10
3.1.4	Gestão dos indicadores . . . . .	11
<b>3.2</b>	<b>Simulação das operações de colheita</b> . . . . .	<b>12</b>
<b>4</b>	<b>METODOLOGIA</b> . . . . .	<b>16</b>
<b>4.1</b>	<b>Classificação metodológica da pesquisa</b> . . . . .	<b>16</b>
<b>4.2</b>	<b>Procedimentos metodológicos</b> . . . . .	<b>16</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÃO</b> . . . . .	<b>23</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b> . . . . .	<b>27</b>
	<b>REFERÊNCIAS</b> . . . . .	<b>29</b>

# 1 Introdução

A atividade de colheita florestal, principalmente em áreas de topografia acidentada e com altos índices de declividade, exige um alto nível de planejamento operacional, sendo orientada por objetivos vinculados à redução de custos e aumento dos índices de produtividade (DE SOUZA, 2013). Segundo Malinovski, Malinovski e Malinovski (2006), aproximadamente 37 variáveis impactam diretamente na produtividade de colheita mecanizada em florestas de Eucalipto, e, dentre elas, a declividade tem um impacto preponderante, o qual quanto maior a declividade, maior a dificuldade de deslocamento dos equipamentos, acarretando em diminuição da produtividade.

Neste sentido, pode-se dizer a identificação das variáveis que influenciam a produtividade das operações florestais se mostra relevante, na medida em que se busca minimizar os custos do processo, aprimorar o uso dos recursos disponíveis e tornar o planejamento operacional mais eficiente (SIMÕES; FENNER, 2010). Assim, ao estudar e identificar tais variáveis cria-se a possibilidade de melhoria das técnicas de previsão da produtividade esperada por área de floresta, o que auxilia no processo de planejamento operacional de atividades florestais (MINETTE *et al.*, 2008).

Martins, Seixas e Stape (2009) afirmam que o volume médio individual da floresta é a variável com maior impacto na produtividade do *harvester*<sup>1</sup>, equipamento este que pode ser utilizado de diferentes formas. Lopes, Oliveira e Roza (2017), por exemplo, destacam a possibilidade de se melhorar a eficiência do *harvester* por meio de ajustes nas configurações operacionais, como a velocidade de corte e o posicionamento das árvores alvo, enquanto Silva (2021) propõe o desenvolvimento de modelos preditivos para estimar a produtividade das operações do equipamento de colheita em diferentes tipos de floresta e condições ambientais.

Gonçalves (2017) destaca a importância de se conhecer a eficiência produtiva das máquinas e equipamentos, em especial, para melhorar a dinâmica do planejamento florestal. Uma alternativa para auxiliar neste processo de planejamento é o uso de ferramentas baseadas em aprendizagem de máquina e/ou a construção de modelos matemáticos e de simulação, em especial, em questões que envolvam cenários de previsão para diferentes contextos operacionais e que exijam uma série de tomadas de decisão ao longo do tempo (GONÇALVES, 2017).

---

<sup>1</sup> Equipamento comumente utilizado no setor madeireiro, que pode ser descrito como um trator de grande dimensão, capaz de derrubar, desgalhar, traçar e empilhar a madeira extraída do perímetro florestal, entre outras aplicações. Disponível em: <<https://armac.com.br/blog/florestal/harvester-florestal/>>. Acesso em: 03 fev. 2024.

Neste contexto, o presente trabalho tem como foco o uso de técnicas de inteligência artificial (IA), particularmente, a construção de uma rede neural, capaz de prever a produtividade dos equipamentos de uma empresa produtora de celulose, com base em seus parâmetros operacionais. A utilização de redes neurais artificiais (RNAs) oferece uma oportunidade promissora para integrar e analisar uma vasta gama de variáveis operacionais de forma eficiente e precisa (SILVA, 2015).

Assim, a proposta deste trabalho se concentrará em incorporar dados relacionados à topografia, condições ambientais, configurações do equipamento e características da floresta à rede neural, para que ela possa ser usada, posteriormente, como um instrumento auxiliar à metodologia atual adotada pela equipe da empresa, proporcionando o aprimoramento do processo de planejamento florestal das atividades de colheita.

## 1.1 Objetivo geral

O objetivo geral deste trabalho consiste na construção de um modelo de rede neural *Multi-Layer Perceptron*<sup>2</sup> (MLP) com foco na predição do volume de madeira, em metros cúbicos extraídos por hora de trabalho, vinculado a um conjunto de variáveis associadas com o planejamento de colheita de eucaliptos de uma empresa produtora de celulose.

### 1.1.1 Objetivos específicos

Para cumprimento do objetivo geral é necessário atender aos seguintes objetivos específicos:

- Caracterizar e descrever o processo de colheita de eucaliptos, com foco na apresentação de algumas das variáveis que influenciam no volume de madeira extraída por hora.
- Desenvolver um modelo de rede neural MLP com o uso das bibliotecas Keras<sup>3</sup> e TensorFlow<sup>4</sup>, em linguagem Python<sup>5</sup>, no ambiente do Google Colab<sup>6</sup>.
- Calibrar os hiperparâmetros do modelo MLP utilizando o algoritmo KerasTuner.
- Analisar e comparar os resultados de predição obtidos pela rede com a metodologia de predição já utilizada na empresa.

<sup>2</sup> Tipo de rede neural composta por camadas de neurônios ligadas entre si por sinapses com pesos. Disponível em: <[https://keras.io/examples/vision/mlp\\_image\\_classification/](https://keras.io/examples/vision/mlp_image_classification/)>. Acesso em 20 abr. 2024.

<sup>3</sup> Biblioteca de código aberto implementada em linguagem Python para utilização em RNAs. Disponível em: <<https://keras.io/>>. Acesso em 20 abr. 2024.

<sup>4</sup> Biblioteca de código aberto com aplicações diversas para aprendizado de máquina. Disponível em: <<https://www.tensorflow.org/>>. Acesso em 20 abr. 2024.

<sup>5</sup> Linguagem de programação de alto nível, utilizada para construção de algoritmos. Disponível em: <<https://www.python.org/>>. Acesso em 20 abr. 2024.

<sup>6</sup> Plataforma on-line que fornece um ambiente de um computador interativo e colaborativo para codificação e execução de algoritmos. Disponível em: <<https://colab.research.google.com/>>. Acesso em 20 abr. 2024.

## 1.2 Justificativa

A aplicação de redes neurais MLP para a predição da produtividade na colheita florestal mecanizada pode ser vista como uma abordagem promissora devido à sua capacidade de lidar com a complexidade dos dados operacionais e das variáveis envolvidas no processo (SILVA, 2015). Considerando a natureza do processo de colheita florestal, onde fatores como topografia do terreno e desempenho das máquinas podem influenciar na produtividade, espera-se que, a utilização de técnicas avançadas de aprendizado de máquina ofereçam uma oportunidade de melhoria do modo operatório de planejamento adotado pela empresa.

Neste sentido, acredita-se que essa abordagem represente um passo importante na busca por métodos mais sofisticados e eficazes de previsão, alinhados com os objetivos de redução de custos e aumento da produtividade da organização em situações futuras. Além disso, este trabalho também tem o potencial de contribuir para a formação e utilização, na prática, de algumas técnicas e ferramentas estudadas pelo autor no curso de Ciência de Dados. Ao desenvolver, aplicar e validar o modelo proposto, o autor pode ampliar seu conhecimento e habilidades em análise de dados e aprendizado de máquina, o que agrega valor ao seu perfil profissional.

## 1.3 Organização do Trabalho

A estrutura deste trabalho é delineada conforme descrito a seguir. O Capítulo 1 apresenta uma introdução sobre o problema de pesquisa, que inclui uma breve contextualização, a apresentação dos objetivos e da justificativa do trabalho. No Capítulo 2 realiza-se uma breve revisão bibliográfica sobre o assunto, com foco na apresentação de alguns indicadores operacionais no processo de colheita florestal, bem como destacando algumas técnicas de predição adotadas em trabalhos disponíveis na literatura. O Capítulo 3 oferece uma síntese concisa do problema de pesquisa abordado. No Capítulo 4 detalha-se a metodologia adotada, incluindo a classificação metodológica da pesquisa, as etapas e técnicas utilizadas para atingir os objetivos propostos. No Capítulo 5 são apresentados os resultados computacionais obtidos, incluindo uma comparação com os resultados do sistema atual da empresa. Por fim, no Capítulo 6, são apresentadas as conclusões do estudo, juntamente com sugestões para futuras investigações relacionadas ao tema.

## 2 Revisão da Literatura

Este capítulo está organizado em duas seções. A primeira seção tem como objetivo apresentar, em linha gerais, o que se tem sobre o problema de pesquisa na literatura. A seção seguinte mostra algumas aplicações de técnicas de aprendizagem de máquina no contexto do problema estudado e que serviu de alicerce para a proposta da pesquisa.

### 2.1 Colheita florestal

A colheita florestal compreende um conjunto de atividades voltadas para a extração de árvores para uso comercial (MACHADO, 2014). Segundo Baggio e Stoehr (1978), esta etapa é crucial e demanda planejamento cuidadoso para garantir eficiência e minimizar impactos ambientais. As práticas de colheita variam desde métodos manuais até a utilização de equipamentos mecanizados avançados (MACHADO, 2014).

A definição de colheita florestal varia conforme diferentes autores e contextos, refletindo a complexidade e as nuances envolvidas nessa operação (CONWAY, 1976; MACHADO, 2014). Conway (1976), por exemplo, descreve como o conjunto de atividades que vão desde o preparo das árvores até seu transporte para o local de uso final, enquanto Machado (2014) conceitua como uma série de operações realizadas na área florestal, com o objetivo de preparar e transportar a madeira para seu destino final, abrangendo as etapas de corte, extração e carregamento.

Essa diversidade de definições evidencia a necessidade de se estudar o ambiente e as variáveis que influenciam no processo de colheita florestal e suas questões históricas (TANAKA, 1986). No Brasil, por exemplo, a colheita florestal desempenha um papel fundamental nos custos de produção dos bens e serviços derivados destes insumos base, sendo responsável por mais da metade (podendo chegar a representar até 80%) do custo final da madeira, por metro cúbico, entregue ao consumidor intermediário ou final (TANAKA, 1986).

Assim, a depender dos custos operacionais, do tipo de máquina e terreno, das condições climáticas, dos recursos disponíveis em cada horizonte de tempo e outras questões-chave, cada empresa deve optar por empregar um tipo específico de método para o processo de colheita (LINHARES *et al.*, 2012).

### 2.1.1 Colheita florestal mecanizada: eficácia e eficiência

A colheita mecanizada tipo *Cut-to-Length* (CTL) é um dos métodos mais eficientes e precisos de colheita florestal (MACHADO, 2014). Neste sistema as árvores são cortadas e processadas diretamente no local de extração, resultando em toras de comprimentos uniformes prontas para o transporte (MACHADO, 2014). De acordo com Bramucci e Seixas (2002), a colheita CTL minimiza danos ao solo e à vegetação circundante, promovendo práticas de colheita mais sustentáveis.

O sistema CTL na colheita florestal é comumente realizado pela combinação do uso dos equipamentos conhecidos como *Harvester* e *Forwarder*, conforme destacado por Bramucci e Seixas (2002), Simões, Fenner e Esperancini (2010) e Linhares *et al.* (2012). O *Harvester* é uma máquina autopropelida com rodado de pneus ou esteiras, responsável pela derrubada, processamento das árvores e execução de operações como desgalhamento e corte em toras com dimensões predeterminadas (DE MIRANDA, 2016).

O *Forwarder* é projetado para a extração de madeira da área de corte para a margem da estrada ou pátio intermediário (DE MIRANDA, 2016). Com um chassi articulado e tração 4×4, 6×6 ou 8×8, além de uma grua hidráulica, o equipamento se destaca pela robustez e resistência, essenciais para superar as condições adversas encontradas no campo (MACHADO, 2014). Em adição, pode-se dizer que, sua eficácia, que reflete nos índices de produtividade, reside na capacidade de carga e descarga, tornando-o fundamental para o transporte eficiente de toras curtas na colheita florestal (DE MIRANDA, 2016).

Neste contexto, pode-se dizer que, a produtividade na colheita florestal é influenciada por uma variedade de fatores, como topografia do terreno, espaçamento das árvores, condições climáticas e eficiência dos equipamentos (MALINOVSKI; MALINOVSKI; MALINOVSKI, 2006). Segundo Linhares *et al.* (2012), a compreensão desses fatores é essencial para otimizar as operações de colheita e aumentar a produtividade de forma sustentável.

De acordo com o estudo conduzido por Malinovski, Malinovski e Malinovski (2006), foram encontradas 37 variáveis-chave que exercem influência significativa na produtividade das máquinas utilizadas na colheita de eucaliptos. Essas variáveis estão relacionadas a diversos aspectos, incluindo características do povoamento florestal, condições do terreno e o planejamento das operações de colheita (MALINOVSKI; MALINOVSKI; MALINOVSKI, 2006).

Portanto, a exploração destes dados no plano florestal de colheita se mostra relevante, frente aos desafios operacionais das empresas que atuam no setor (SILVA, 2017), o que pode ser facilitado por meio de modelos e técnicas de aprendizagem de máquina, por exemplo (SILVA, 2021).

## 2.2 Uso de inteligência artificial para o planejamento florestal de colheita

O avanço da tecnologia impulsionou o surgimento de ferramentas computacionais, baseadas nos conceitos de IA, capazes de auxiliar no processo de previsão e/ou otimização de diversos tipos de variáveis e solução de problemas nos setores primário, secundário e terciário (FLÓREZ, 2020; SIQUEIRA, 2021; LUDERMIR, 2021). Essa ampla capacidade de aplicação e utilização de tais ferramentas tem se mostrado relevante quando se deseja realizar um plano florestal de colheita mais robusto, tal como destacado nos trabalhos apresentados a seguir.

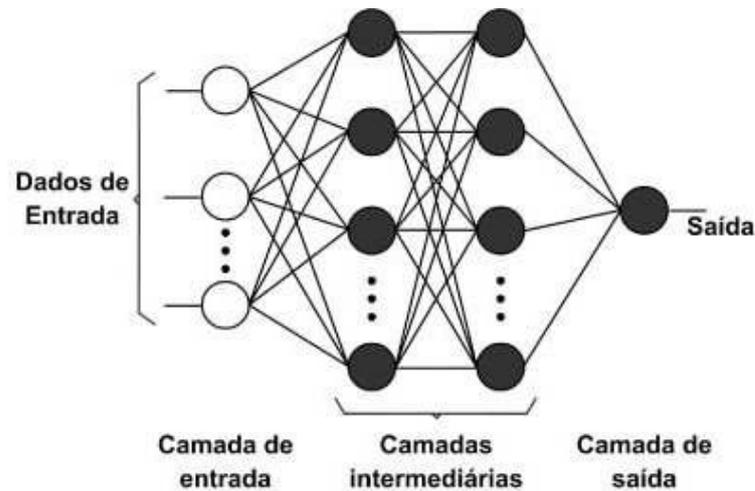
Silva (2021) investiga a produtividade do eucalipto no Brasil, reconhecendo que vários fatores influenciam seu crescimento, incluindo clima, solo e manejo. O trabalho propõe um modelo 3-PG integrado com RNAs, visando melhorar a precisão das previsões. Santos (2021) utiliza redes neurais convencionais e profundas (*deep learning*), e as compara com um modelo de regressão, capazes de projetar diâmetro, altura total e sobrevivência em povoamentos de eucalipto. Para comparar os resultados, Santos (2021) utiliza algumas estatísticas de desempenho dos métodos, que incluem o coeficiente de correlação e o erro quadrático médio.

Binoti *et al.* (2022) investigam a importância das variáveis preditoras, incluindo fatores silviculturais, climáticos e de manejo, na produtividade de povoamentos de eucalipto ao final da rotação. Utilizando um método de perturbação em modelos de RNAs, Binoti *et al.* (2022) analisaram um conjunto de dados de 320 talhões de plantios de eucalipto no norte de Minas Gerais. Já Borba (2022) aborda a perspectiva da aplicação da IA no agronegócio da Caatinga, destacando a importância de entender as implicações sociais, políticas e econômicas dessa tecnologia em um contexto de mudanças.

Mais especificamente, as redes neurais MLP, metodologia adotada neste trabalho, são um tipo de modelo de aprendizado de máquina que consiste em múltiplas camadas de neurônios interconectados, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (FLECK *et al.*, 2016). Essas redes são capazes de aprender relações complexas nos dados e são amplamente utilizadas em problemas de regressão e classificação devido à sua capacidade de lidar com dados não-lineares (FLECK *et al.*, 2016). A Figura 1 mostra um exemplo de rede MLP que possui dados de entradas, dois níveis de camadas intermediárias e uma única informação de saída. (FIORIN *et al.*, 2011)

Alguns estudos têm demonstrado a eficácia das MLPs na predição da produtividade na colheita florestal. Silva (2015) utiliza uma MLP para estimar a produtividade do *Forwarder* na extração de madeira de eucalipto. Os resultados mostraram que a MLP foi capaz de fornecer boas estimativas de produtividade, contribuindo para uma melhor tomada de decisão no planejamento das operações de colheita.

Figura 1 – Representação gráfica de uma rede MLP



Fonte: (FIORIN *et al.*, 2011, p. 1309-6).

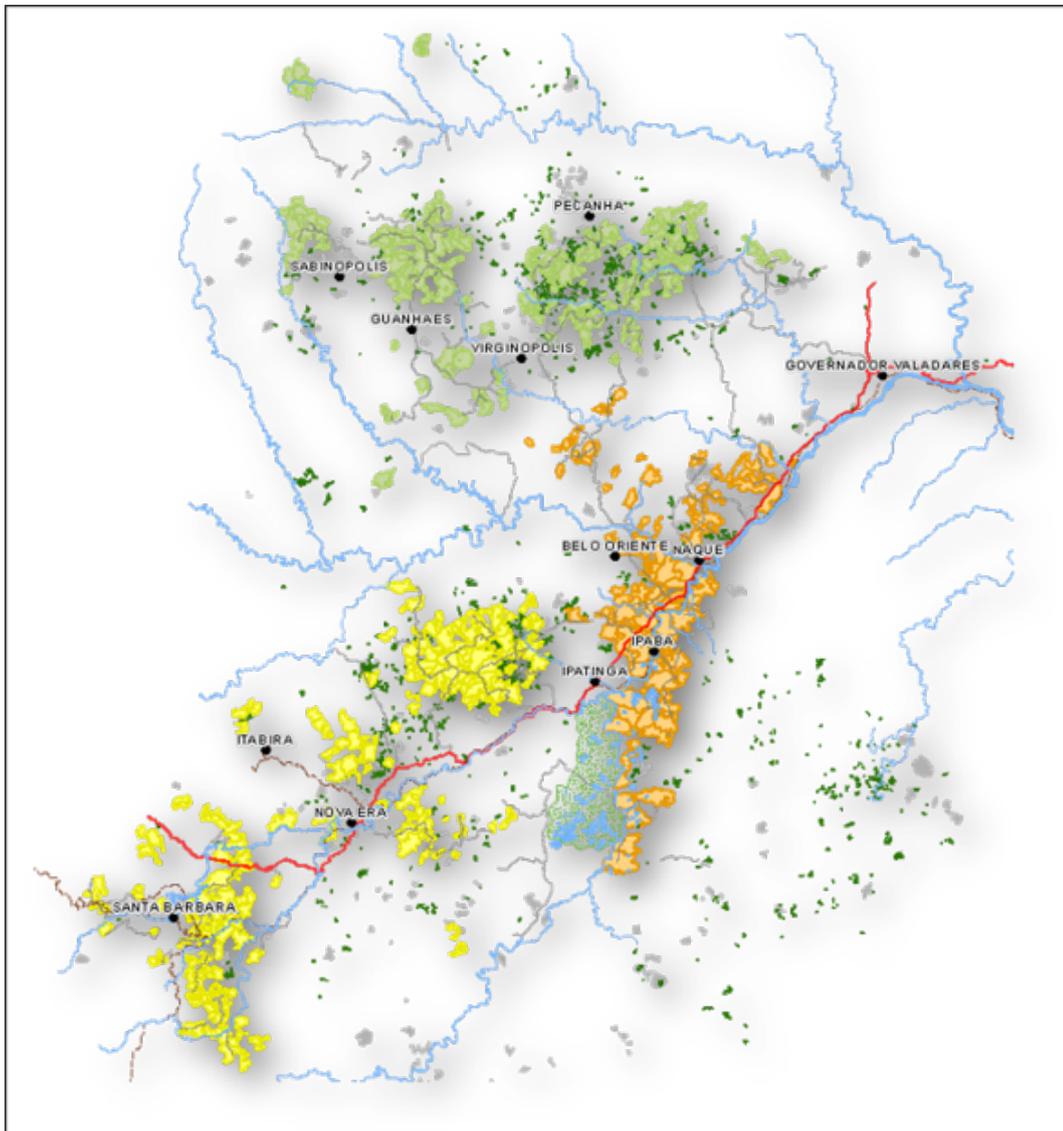
Lacerda *et al.* (2022) utilizam MLPs para predição da disponibilidade mecânica na colheita mecanizada de florestas de eucalipto. O objetivo do estudo por eles proposto foi desenvolver um modelo preditivo capaz de estimar a disponibilidade mecânica das máquinas com base em dados reais de operação e manutenção.

Os últimos dois estudos destacados anteriormente evidenciam o potencial do uso de redes neurais MLP para melhorar a eficiência e a precisão da predição de produtividade na colheita florestal. Por fim, é importante destacar que o objetivo desta seção não se concentra em apresentar toda a literatura sobre o assunto, mas indicar alguns dos trabalhos recentes que serviram de base para a realização desta pesquisa.

### 3 Descrição do problema

Para descrever ambiente do qual esta pesquisa foi realizada é importante destacar que se trata do escopo das operações de colheita de uma empresa produtora de celulose localizada na região leste do Estado de Minas Gerais. Mais especificamente, são utilizados dados de operação de colheita florestal mecanizada, em áreas que possuem plantios de Eucalyptus. A representação cartográfica exibida na Figura 2 demonstra a disposição espacial e a abrangência dos projetos florestais da organização, sendo que as cores referem-se às três regionais florestais de atuação da empresa.

Figura 2 – Mosaico das áreas dos projetos



Fonte: Imagem retirada do banco de imagens interno da empresa.

Na empresa foco deste estudo, anualmente, é elaborado o planejamento de produção, etapa considerada essencial em diversos setores industriais, incluindo a indústria florestal, onde metas produtivas são estabelecidas visando alcançar objetivos específicos, para cada uma das regiões indicadas na Figura 2. A definição de metas produtivas anuais pela empresa permite o estabelecimento de diretrizes claras para a produção de madeira ao longo do período de colheita planejado.

Essa abordagem está alinhada com visão estratégica descrita por diversos pesquisadores que estudaram questões de planejamento de produção na indústria florestal (WERNEBURG, 2015). No Brasil, o planejamento em grandes empresas florestais, tem sido focado em estratégias para gerenciar as operações e otimizar a produção de madeira com base em metas preestabelecidas (WERNEBURG, 2015).

O alcance dessas metas de produção está intrinsecamente ligado ao cumprimento de diversos indicadores-chave do processo produtivo, que desempenham um papel relevante na eficiência e no desempenho global das operações. Alguns destes indicadores são apresentados a seguir.

## 3.1 Indicadores de desempenho na colheita florestal

Os indicadores de disponibilidade mecânica, eficiência operacional e produtividade desempenham papéis fundamentais na avaliação do desempenho das operações de colheita florestal da empresa. Além disso, a gestão desses indicadores envolve a coleta, análise e interpretação dos dados operacionais para monitorar o desempenho das máquinas e equipes de trabalho ao longo do tempo.

### 3.1.1 Indicador de disponibilidade mecânica

O indicador que mede a Disponibilidade Mecânica ( $D_t$ ) representa o tempo, em horas, em que as máquinas estão operacionais e prontas para o trabalho à cada período de tempo  $t \in T$ . A Equação (3.1) mostra como é feito o cálculo de  $D_t$ , a partir da razão entre o tempo total de operação do equipamento e o tempo total disponível, expressa como um percentual (LINHARES *et al.*, 2012).

$$D_t = \frac{\alpha_t}{\beta_t} (100\%) \quad \forall t \in T \quad (3.1)$$

Na Equação (3.1) as variáveis  $\alpha_t$  representam o tempo total em que as máquinas estão operando durante o período  $t \in T$ , enquanto as variáveis  $\beta_t$  indicam o tempo total em que as máquinas deveriam estar disponíveis para operação durante no período  $t \in T$ .

### 3.1.2 Indicador de eficiência operacional

O indicador de Eficiência Operacional ( $E_t$ ) mede o tempo efetivamente utilizado, em horas, para as atividades produtivas em cada período  $t \in T$ . A Equação (3.2) mostra o cálculo de  $E_t$  como a razão entre a produção real e a produção potencial da máquina, expressa como um percentual (LINHARES *et al.*, 2012).

$$E_t = \frac{\gamma_t}{\alpha_t} (100\%) \quad \forall t \in T \quad (3.2)$$

Pela Equação (3.2) é possível notar que as horas de produção efetivas, representadas pelas variáveis  $\gamma_t$ , sinalizam o tempo total gasto em atividades produtivas durante o período  $t \in T$ . Note que as variáveis  $\alpha_t$  são as mesmas utilizadas no cálculo de  $D_t$ .

### 3.1.3 Indicador de produtividade

A Produtividade ( $P_t$ ), medida em metros cúbicos por hora, quantifica o volume de madeira colhida em relação ao tempo gasto em cada período  $t \in T$ . Conforme mostrado na Equação (3.3) o valor de  $P_t$  é definido como a razão entre a quantidade de madeira colhida e o tempo necessário para realizar essa operação, expressa em metros cúbicos por hora ( $\text{m}^3/\text{h}$ ), para cada horizonte de tempo  $t \in T$  (SILVA, 2017).

$$P_t = \frac{v_t}{\tau_t} \quad \forall t \in T \quad (3.3)$$

Os valores de  $v_t$  informam a quantidade de produto gerado durante o período de interesse, em metros cúbicos ( $\text{m}^3$ ), em um período  $t \in T$ , assim como os valores de  $\tau_t$  indicam o tempo total em que as máquinas estiveram em operação durante o período  $t \in T$ , no caso da empresa, medido em horas (h).

É importante destacar que o processo de modelagem e calibração da produtividade na empresa, nos dias atuais, é realizado utilizando um modelo logarítmico. Para isso, são empregados dados provenientes de dois anos de colheita, geralmente obtidos a partir do boletim de apropriação.

Esses dados são submetidos a uma análise de consistência para garantir sua qualidade e confiabilidade. Em seguida, são ajustados modelos considerando o rendimento em relação ao Volume Médio Individual (VMI). As curvas resultantes são então calibradas com base nas médias estabelecidas durante reuniões de planejamento da equipe designada pela empresa. A Figura 3 representa a curva de produtividade esperada, em metros cúbicos por hora ( $\text{m}^3/\text{h}$ ), por classe de VMI, manejo, produto e região sendo:

- VMI: volume médio individual ( $\text{m}^3/\text{árvore}$ );
- Manejo: PD - áreas com topografia de 0 a 28°; GW áreas com topografia de 28 a 36°;

Figura 3 – Exemplo de planilha de dados utilizada para a construção das curvas de produtividade

VMI (m <sup>3</sup> /arv)	Rendimento (m <sup>3</sup> /h)			VMI (m <sup>3</sup> /arv)	Rendimento (m <sup>3</sup> /h)			VMI (m <sup>3</sup> /arv)	Rendimento (m <sup>3</sup> /h)			VMI (m <sup>3</sup> /arv)	Rendimento (m <sup>3</sup> /h)			VMI (m <sup>3</sup> /arv)	Rendimento (m <sup>3</sup> /h)			VMI (m <sup>3</sup> /arv)	Rendimento (m <sup>3</sup> /h)		
	PD	GW			PD	GW																	
		SC	CC			SC	SC			CC	SC			SC	CC			SC	SC			CC	SC
0,10	8,18	6,08	4,07	0,10	10,95	10,82	4,41	0,10	8,25	12,57	3,71	0,10	8,36	9,25	4,10	0,10	7,15	7,12	3,62				
0,11	9,68	7,58	5,02	0,11	12,04	11,95	5,17	0,11	9,39	13,72	4,57	0,11	9,74	10,63	4,95	0,11	8,20	8,17	4,38				
0,12	11,05	8,95	5,89	0,12	13,04	12,99	5,87	0,12	10,43	14,76	5,35	0,12	11,01	11,89	5,74	0,12	9,16	9,13	5,07				
0,13	12,30	10,20	6,69	0,13	13,96	13,94	6,51	0,13	11,40	15,72	6,07	0,13	12,17	13,06	6,46	0,13	10,04	10,01	5,71				
0,14	13,47	11,37	7,43	0,14	14,82	14,83	7,10	0,14	12,28	16,61	6,74	0,14	13,24	14,13	7,12	0,14	10,85	10,82	6,31				
0,15	14,55	12,45	8,12	0,15	15,61	15,65	7,66	0,15	13,11	17,44	7,36	0,15	14,24	15,13	7,74	0,15	11,61	11,58	6,86				
0,16	15,56	13,46	8,77	0,16	16,35	16,42	8,17	0,16	13,89	18,21	7,94	0,16	15,18	16,07	8,33	0,16	12,32	12,29	7,38				
0,17	16,52	14,42	9,37	0,17	17,05	17,14	8,66	0,17	14,61	18,94	8,49	0,17	16,06	16,94	8,87	0,17	12,99	12,96	7,86				
0,18	17,41	15,31	9,95	0,18	17,71	17,82	9,12	0,18	15,30	19,63	9,00	0,18	16,88	17,77	9,39	0,18	13,62	13,59	8,32				
0,19	18,26	16,16	10,49	0,19	18,33	18,47	9,55	0,19	15,95	20,28	9,49	0,19	17,67	18,56	9,87	0,19	14,21	14,18	8,75				
0,20	19,07	16,97	11,00	0,20	18,92	19,08	9,96	0,20	16,56	20,89	9,95	0,20	18,41	19,30	10,33	0,20	14,78	14,75	9,16				
0,21	19,83	17,73	11,49	0,21	19,48	19,66	10,35	0,21	17,15	21,48	10,39	0,21	19,12	20,01	10,77	0,21	15,31	15,28	9,55				
0,22	20,56	18,46	11,95	0,22	20,01	20,21	10,72	0,22	17,71	22,04	10,81	0,22	19,79	20,68	11,19	0,22	15,83	15,80	9,92				
0,23	21,26	19,16	12,40	0,23	20,53	20,74	11,08	0,23	18,24	22,57	11,21	0,23	20,44	21,33	11,59	0,23	16,32	16,28	10,28				
0,24	21,93	19,83	12,82	0,24	21,02	21,25	11,42	0,24	18,75	23,08	11,59	0,24	21,06	21,94	11,97	0,24	16,78	16,75	10,62				
0,25	22,57	20,47	13,23	0,25	21,48	21,74	11,75	0,25	19,24	23,57	11,96	0,25	21,65	22,54	12,34	0,25	17,23	17,20	10,95				
0,26	23,19	21,09	13,62	0,26	21,94	22,21	12,06	0,26	19,71	24,04	12,31	0,26	22,22	23,10	12,69	0,26	17,66	17,63	11,26				
0,27	23,78	21,68	14,00	0,27	22,37	22,66	12,36	0,27	20,17	24,49	12,65	0,27	22,76	23,65	13,03	0,27	18,08	18,05	11,56				
0,28	24,35	22,25	14,36	0,28	22,79	23,09	12,65	0,28	20,60	24,93	12,98	0,28	23,29	24,18	13,36	0,28	18,48	18,45	11,85				
0,29	24,90	22,80	14,72	0,29	23,19	23,51	12,93	0,29	21,02	25,35	13,29	0,29	23,80	24,69	13,68	0,29	18,87	18,83	12,13				
0,30	25,43	23,33	15,05	0,30	23,58	23,91	13,20	0,30	21,43	25,76	13,60	0,30	24,29	25,18	13,98	0,30	19,24	19,21	12,40				
0,31	25,95	23,85	15,38	0,31	23,96	24,30	13,47	0,31	21,82	26,15	13,89	0,31	24,77	25,65	14,28	0,31	19,60	19,57	12,67				

Fonte: Captura de tela de dados internos da empresa, editada pelo autor.

- Produto: CC - madeira com casca; SC - madeira sem casca;
- Região: cada tabela representa uma região da empresa.

### 3.1.4 Gestão dos indicadores

Todos os indicadores citados anteriormente são fundamentais para avaliar o desempenho das operações florestais, buscando a eficácia do uso de equipamentos e recursos, bem como possibilitar a identificação de eventuais melhorias e ajustes que sejam necessários no plano operacional de colheita. Assim, o monitoramento contínuo desses indicadores permite à empresa tomar decisões com base no histórico do desempenho operacional, visando maximizar a produção, minimizar os custos e garantir a sustentabilidade do negócio a longo prazo.

O monitoramento destes indicadores na empresa é conduzido por meio de painéis com interface (*dashboards*) da plataforma Power BI<sup>7</sup>. As fontes de dados para alimentar a plataforma de visualização de dados do Power BI são advindas um banco de dados multimodelo, conhecido como SAP HANA<sup>8</sup> para processamento de dados, que inclui o módulo de Gestão de Processos Florestais (GPF). Todas as entradas de dados de produção são realizadas por meio de sistemas de telemetria e apontamento digital instalados nas máquinas de colheita. Esses dados são inseridos diretamente pelos operadores em campo e transmitidos por um sistema de transmissão híbrido, que utiliza tanto *General Packet Radio Service* (GPRS) quanto satélites.

<sup>7</sup> Serviço de análise de negócios e análise de dados da desenvolvedora Microsoft. Disponível em: <<https://www.microsoft.com/pt-br/power-platform/products/power-bi/>>. Acesso em 20 abr. 2024.

<sup>8</sup> Sistema de planejamento de recursos empresariais, também conhecido como *Enterprise Resource Planning* (ERP). Disponível em: <<https://www.sap.com/brazil/products/technology-platform/hana/what-is-sap-hana.html>>. Acesso em 20 abr. 2024.

A Figura 4 apresenta o painel de monitoramento da atividade de colheita florestal, exibindo visualmente o desempenho em relação às metas definidas para os principais indicadores da atividade, bem como a produção alcançada em comparação com o volume planejado. Esses indicadores são detalhados por frente de operação e também são apresentados em um formato acumulado mensal.

Figura 4 – Exemplo de imagem de um *dashboard* de produção de colheita adotado pela empresa



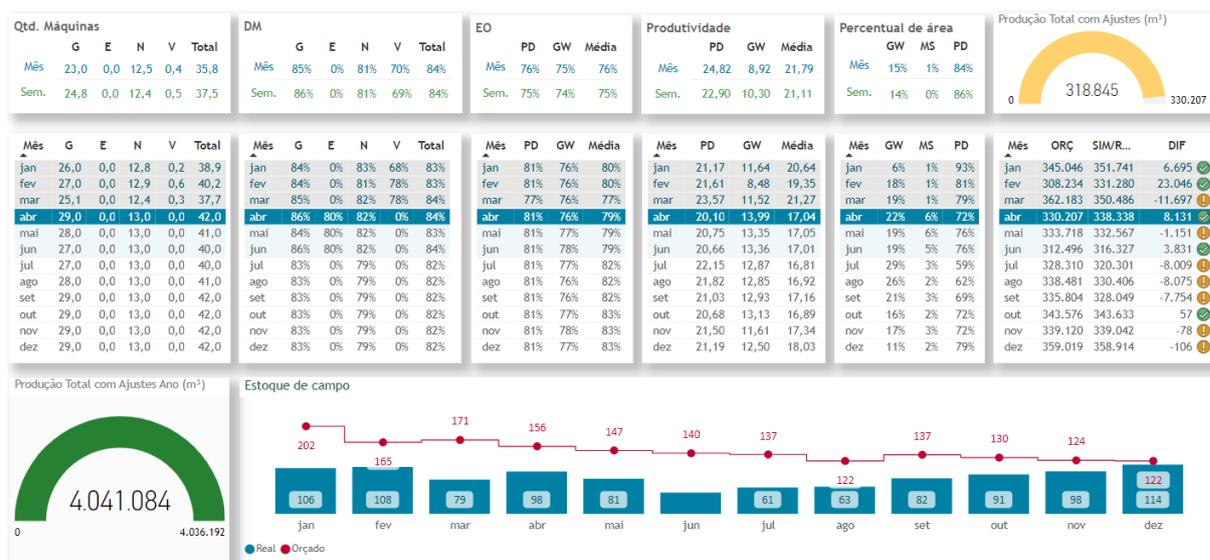
Fonte: Captura de tela de dados internos da empresa, editada pelo autor.

### 3.2 Simulação das operações de colheita

Durante a execução das atividades operacionais é possível que ocorram alterações nas variáveis, o que pode afetar o alcance das metas preestabelecidas para cada um dos indicadores processo. Para mitigar os impactos dessas mudanças e assegurar o alcance das metas de produção, foi desenvolvido um simulador operacional, capaz de estimar os novos valores esperados para os indicadores após as alterações propostas.

O uso do simulador tem como foco poder realocar os recursos para neutralizar perdas e manter a produção dentro dos parâmetros planejados. Essa abordagem é fundamentada em princípios de gestão de operações e análise preditiva, visando otimizar o desempenho e a eficiência do processo produtivo (SILVA, 2021). A Figura 5 ilustra o painel do simulador operacional de colheita, destacando, na seção superior, os resultados reais obtidos durante um mês e semana de operação, que servem como referência para a análise dos gestores na atualização dos indicadores para os próximos dois meses.

Figura 5 – Simulação operacional de colheita



Fonte: Captura de tela de dados internos da empresa, editada pelo autor.

Pela Figura 5 é possível notar que, a atualização dos indicadores permite representar graficamente o comportamento dos estoques de madeira no campo, bem como a projetar o alcance da produção planejada para o mês e para o ano.

A definição dos parâmetros da simulação é conduzida mediante a inserção manual de dados de entrada organizados em uma lista específica no ambiente corporativo, acessada por meio do portal SharePoint<sup>9</sup>. Nessa lista, os supervisores responsáveis por cada frente de colheita realizam projeções para os próximos 90 dias, com base nos indicadores alcançados nos últimos 30 dias e as eventuais alterações necessárias em função da percepção de mudanças do contexto produtivo.

Essas projeções via simulação envolvem ajustes nos parâmetros orçamentários, podendo ser aumentados ou reduzidos conforme necessário, a fim de melhorar o desempenho operacional e garantir o alcance das metas preestabelecidas. A Figura 6 apresenta uma lista que abriga os indicadores operacionais passíveis de ajustes pelos gestores. A ideia é que, uma vez modificados, seja possível realizar uma análise mais precisa e dinâmica do desempenho operacional por meio da simulação.

Em suma, pode-se dizer que, a essência da proposta deste estudo consiste em oferecer uma previsão da produtividade (m<sup>3</sup>/h) com base em registros históricos, os quais são processados por meio de uma rede neural MLP, que, posteriormente, possa retroalimentar o simulador adotado pela empresa.

<sup>9</sup> Plataforma que permite a criação e edição de portais e intranets empresariais, gestão de conteúdos, gestão documental, criação de portais colaborativos e publicação de aplicações web. Disponível em: <<https://www.microsoft.com/pt-br/microsoft-365/sharepoint/collaboration/>>. Acesso em 20 abr. 2024.

Figura 6 – Lista de *SharePoints* com indicadores alterados

SIMULACAOINDICADORES

<input type="radio"/> FRENTE ▾	FROTA ▾	MES ▾	ANO ▾	PERAREAGW ▾	PERAREAMS ▾	DMJDG ▾	DMJDE ▾	DMPON ▾	DMPOV ▾	EOGW ▾	EOPD ▾	PRODGW ▾	PRODPD ▾	
<input type="radio"/> CO	HG	1	2.024	0,25	0,1				0,81		0,76	0,8	14	20
<input type="radio"/> CO	FG	1	2.024	0,55	0,11				0,8		0,8	0,85	19	31
<input type="radio"/> GN	HG	1	2.024	0,04	0,01	0,82	0,8				0,8	0,79	18,44	23,3
<input type="radio"/> GN	FG	1	2.024	0,04	0,01	0,89	0,8				0,8	0,84	18,23	32,5
<input type="radio"/> PI	HG	1	2.024	0,08	0,01	0,86					0,72	0,83	10	15
<input type="radio"/> PI	FG	1	2.024	0,1	0,01	0,84					0,75	0,85	16	24
<input type="radio"/> RD	HG	1	2.024	0,02	0,01	0,8			0,83		0,77	0,83	9	19
<input type="radio"/> RD	FG	1	2.024	0,01	0,01	0,78			0,85		0,82	0,85	17	28
<input type="radio"/> SB	HG	1	2.024	0,05	0,01	0,87					0,79	0,82	15	25
<input type="radio"/> SB	FG	1	2.024	0,05	0,01	0,88					0,77	0,88	18,5	31
<input type="radio"/> CO	HG	2	2.024	0,25	0,03				0,85		0,8	0,83	14,71	22
<input type="radio"/> CO	FG	2	2.024	0,15	0,03				0,84		0,8	0,86	15	32

Fonte: Captura de tela de dados internos da empresa, editada pelo autor.

Assim, espera-se que seja possível inserir no simulador um conjunto de parâmetros mais ajustados ao contexto real da colheita, visando melhorar a precisão das previsões obtidas pela ferramenta.

## 4 Metodologia

### 4.1 Classificação metodológica da pesquisa

Esse trabalho adota uma abordagem metodológica de natureza aplicada (FLEURY; WERLANG, 2017), uma vez que busca resolver um problema prático, que representa o contexto específico da colheita florestal mecanizada de uma empresa. Seguindo uma metodologia de modelagem e simulação (CAUCHICK-MIGUEL *et al.*, 2018), o estudo se baseia na construção de um modelo de rede neural, que, combinada com o uso de um simulador computacional, visa prever o desempenho das operações de colheita florestal. Essa abordagem permite explorar as relações quantitativas entre variáveis operacionais e o rendimento das máquinas (CAUCHICK-MIGUEL *et al.*, 2018).

Em relação aos objetivos da pesquisa, a proposta de pesquisa deste trabalho pode ser classificada como empírico-normativa (CAUCHICK-MIGUEL *et al.*, 2018). Tal classificação se justifica em função da característica do modelo em buscar prescrever o desempenho das operações de colheita florestal mecanizada com base em evidências e ajustes empíricos dos parâmetros do algoritmo. Assim, este estudo busca estabelecer padrões e diretrizes que permitam, no futuro, melhorar a dinâmica do processo de planejamento da colheita florestal da empresa.

### 4.2 Procedimentos metodológicos

Para condução da pesquisa, inicialmente, foram levantados os dados de produção das máquinas de colheita no período de janeiro de 2022 a dezembro de 2023, o que corresponde a um total de 2.804 linhas de dados, que incluem dados produtivos tanto do processo de corte (via *Harvesters*) quanto de baldeio (via *Forwarders*). Nesta etapa da pesquisa foram utilizados diferentes tipos de softwares para organização, codificação e visualização de dados, que incluem o Power BI, o ArcGIS<sup>10</sup>, o Microsoft Excel<sup>11</sup> e o Google Colab.

Ademais, a coleta de dados compreendeu um banco de dados composto por registros de produção, características do talhão, classificação de manejo, classificação da madeira, dados do inventário florestal e dados topográficos do talhão. Entre os dados levantando, àqueles que de fato tiveram maior grau de relevância são os vinculados às atividades de baldeio via *Forwarders*, que são o foco principal deste trabalho.

<sup>10</sup> Sistema de informação geográfica (*Geographic Information System* - GIS) utilizado para criar, gerenciar, compartilhar e analisar dados espaciais. Disponível em: <<https://www.arcgis.com/index.html>>. Acesso em 20 abr. 2024.

<sup>11</sup> Software comumente utilizado para edição e construção de planilhas eletrônicas. Disponível em: <<https://www.microsoft.com/pt-br/microsoft-365/excel>>. Acesso em 20 abr. 2024.

Para modelar a produtividade dos *Forwarders* por meio de uma rede MLP, uma planilha eletrônica foi organizada (ver Figura 7), contendo todos os parâmetros de entrada relevantes, previamente identificados, que, na opinião da equipe, mais poderiam impactar o desempenho da extração florestal mecanizada do equipamento. Dentre estes parâmetros, os dados dos níveis de produtividade das máquinas, em metros cúbicos por hora (m<sup>3</sup>/h), sob essas condições específicas são considerados importantes, por serem as referências-chave para o cálculo da produtividade pela empresa nos dias atuais.

No processo de preparação dos dados foi realizado um procedimento de remoção de registros imprecisos ou vazios e valores discrepantes, como a retirada do dados com VMI inferior a 0,05 m<sup>3</sup>/arv e superior a 0,8 m<sup>3</sup>/arv, por não representarem característica de florestas regulares no contexto da empresa, e a exclusão dos registros com valores de produção (m<sup>3</sup>) ou horas produtivas (h) menores ou iguais à zero, por exemplo.

Os dados contidos na planilha foram carregados dentro do ambiente de desenvolvimento do Google Colab. Inicialmente, utilizando a biblioteca Pandas<sup>12</sup> do Python, os dados foram organizados em conjuntos. Nesse processo, foram realizadas operações de pré-processamento para filtrar e limpar os dados, removendo informações irrelevantes para o treinamento das RNAs. Os conjuntos resultantes, conforme mostrado no Quadro 1 são as variáveis de entrada do modelo que serão utilizadas como características para o treinamento do modelo de RNA.

Quadro 1 – Caracterização dos conjuntos de dados de entrada do modelo

Conjunto	Descrição
FRENTE_AJUS	Frente operacional de colheita por região.
MANEJO	Característica das áreas de operação padrão (PD) e áreas de operação com guincho auxiliar de tração (GW).
PRODUTO	Classificação de madeira com casca (CC) ou sem casca (SC).
COMP	Comprimento da madeira processada: 3,3m ou 6,50m.
VMI_ARRED	Volume médio individual da floresta base inventário pré-corte, em metros cúbicos por árvore (m <sup>3</sup> /arv).
PD_1_POND	Percentual de áreas de 0 a 15°.
PD_2_POND	Percentual de áreas de 16 a 28°.
GW_1_POND	Percentual de áreas de 29 a 32°.
GW_2_POND	Percentual de áreas de 33 a 36°.
VCCC	Volume de madeira, em metros cúbicos por hectare (m <sup>3</sup> /he), com desconto de casca.
PERC_PD_POND	Percentual de áreas de 0 a 28° sobre o total de área do talhão.
PERC_GW_POND	Percentual de áreas de 29 a 36° sobre o total de área do talhão.

A Figura 8 ilustra como os dados são visualizados no ambiente do Google Colab. Ademais, o modelo proposto possui uma única variável de saída REND, que indica rendimento dos equipamentos, em metros cúbicos por hora (m<sup>3</sup>/h), quando sujeito a diferentes condições de terreno, inclinação, dimensões de manejo e o tipo de madeira que são baldeados, em cada cada talhão de uma frente operacional.

<sup>12</sup> Biblioteca de código aberto comumente utilizada como ferramenta de análise e manipulação de dados. Disponível em: <<https://pandas.pydata.org/>>. Acesso em: 02 mai. 2024.

Figura 7 – Planilha que ilustra os dados de entrada

ANO	FRENTE	FRENTE_AJUS	TALHAO	FROTA	MANEJO	PRODUTO	COMP	VMI_ARRED	PRODUCAO	HORAS_PRODUTIVAS	REND	PD_1_POND	PD_2_POND	GW_1_POND	GW_2_POND	PERC_PD_POND	PERC_GW_POND	MES_INI	MES_FIM	VCCC
2023	GN	GN	GNSACR00661P90-001	FG	GW	SC	6,5	0,85	405,08	11,9	34,04	0	0	0,814037576	0,185962424	0,980998611	0,019001389	Out	Out	440,52
2023	GN	GN	GNSACR00661P90-001	HG	GW	SC	6,5	0,85	405,08	24,5	16,53	0	0	0,814037576	0,185962424	0,980998611	0,019001389	Set	Set	440,52
2023	GN	GN	GNSACR00661P90-001	FG	PD	SC	6,5	0,85	11083,93	409,6	27,06	0,490256738	0,509743262	0	0	0,980998611	0,019001389	Out	Out	440,52
2023	GN	GN	GNSACR00661P90-001	HG	PD	SC	6,5	0,85	11083,93	420,4	26,36	0,490256738	0,509743262	0	0	0,980998611	0,019001389	Set	Set	440,52
2023	GN	GN	GNSACR00661P90-002	FG	GW	SC	6,5	1,08	266,57	16,1	16,57	0	0	0,696881408	0,303118592	0,7045164	0,2954836	Out	Out	563,21
2023	GN	GN	GNSACR00661P90-002	HG	GW	SC	6,5	1,08	266,57	18,6	14,35	0	0	0,696881408	0,303118592	0,7045164	0,2954836	Set	Set	563,21
2023	GN	GN	GNSACR00661P90-002	FG	PD	SC	6,5	1,08	5194,1	172,1	30,19	0,200387447	0,799612553	0	0	0,7045164	0,2954836	Out	Out	563,21
2023	GN	GN	GNSACR00661P90-002	HG	PD	SC	6,5	1,08	5194,1	221,6	23,44	0,200387447	0,799612553	0	0	0,7045164	0,2954836	Set	Set	563,21
2023	GN	GN	GNSACR00673P11-001	FG	PD	CC	3,3	0,38	3440,31	145,6	23,63	0,37	0,63	0	0	0,92263318	0,07736682	Mai	Mai	361,00
2023	GN	GN	GNSACR00673P11-001	HG	PD	CC	3,3	0,38	3552,19	251,2	14,14	0,37	0,63	0	0	0,92263318	0,07736682	Mai	Mai	360,99
2023	GN	GN	GNSACR00673P11-001	FG	PD	SC	6,5	0,51	14175,3	339	41,82	0,37	0,63	0	0	0,92263318	0,07736682	Mai	Mai	361,00
2023	GN	GN	GNSACR00673P11-001	HG	PD	SC	6,5	0,50	14175,28	380	37,3	0,37	0,63	0	0	0,92263318	0,07736682	Mai	Mai	361,00
2023	GN	GN	GNSACR00673P11-002	HG	GW	SC	6,5	0,59	110,58	2,7	40,95	0	0	0,78	0,22	0,986990381	0,013009619	Mai	Mai	486,78
2023	GN	GN	GNSACR00673P11-002	FG	PD	SC	6,5	0,59	26859,51	760,1	35,34	0,7	0,3	0	0	0,986990381	0,013009619	Mai	Mai	486,78
2023	GN	GN	GNSACR00673P11-002	HG	PD	SC	6,5	0,59	26859,49	806,7	33,29	0,7	0,3	0	0	0,986990381	0,013009619	Mai	Mai	486,78
2023	GN	GN	GNSACR00673P11-003	FG	GW	SC	6,5	0,44	241,42	15,3	15,83	0	0	0,8	0,2	0,925042103	0,074957897	Mai	Mai	378,59
2023	GN	GN	GNSACR00673P11-003	HG	GW	SC	6,5	0,44	241,42	20,9	11,55	0	0	0,8	0,2	0,925042103	0,074957897	Mai	Mai	378,59
2023	GN	GN	GNSACR00673P11-003	FG	PD	CC	3,3	0,43	3369,67	183,2	18,39	0,33	0,67	0	0	0,925042103	0,074957897	Mai	Mai	378,59
2023	GN	GN	GNSACR00673P11-003	HG	PD	CC	3,3	0,43	3479,26	284	12,25	0,33	0,67	0	0	0,925042103	0,074957897	Mai	Mai	378,59
2023	GN	GN	GNSACR00673P11-003	FG	PD	SC	6,5	0,44	14288,44	419,4	34,07	0,33	0,67	0	0	0,925042103	0,074957897	Mai	Mai	378,59
2023	GN	GN	GNSACR00673P11-003	HG	PD	SC	6,5	0,44	14288,44	540,1	26,45	0,33	0,67	0	0	0,925042103	0,074957897	Mai	Mai	378,59
2023	GN	GN	GNSACR00673P11-007	FG	GW	SC	6,5	0,54	131,71	4,2	31,21	0	0	0,84	0,16	0,961577889	0,038422111	Jun	Jun	454,43
2023	GN	GN	GNSACR00673P11-007	HG	GW	SC	6,5	0,54	131,72	11,3	11,62	0	0	0,84	0,16	0,961577889	0,038422111	Mai	Jun	454,43
2023	GN	GN	GNSACR00673P11-007	FG	PD	SC	6,5	0,54	11734,32	318,2	36,88	0,33	0,67	0	0	0,961577889	0,038422111	Mai	Jun	454,43

Fonte: Elaborado pelo autor.

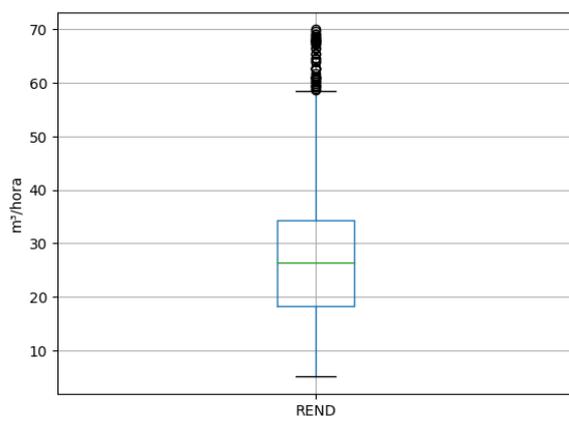
Figura 8 – Dados de entrada carregados no ambiente do Google Colab

FRENTE_AJUS	MANEJO	PRODUTO	COMP	VMI_ARRED	REND	PD_1_POND	PD_2_POND	GW_1_POND	GW_2_POND	PERC_PD_POND	PERC_GW_POND	VCCC
GN	GW	SC	6.5	0.846271	34.04	0.000000	0.000000	0.814038	0.185962	0.980999	0.019001	440.523
GN	PD	SC	6.5	0.846271	27.06	0.490257	0.509743	0.000000	0.000000	0.980999	0.019001	440.523
GN	GW	SC	6.5	1.075493	16.57	0.000000	0.000000	0.696881	0.303119	0.704516	0.295484	563.206
GN	PD	SC	6.5	1.075493	30.19	0.200387	0.799613	0.000000	0.000000	0.704516	0.295484	563.206
GN	PD	CC	3.3	0.381807	23.63	0.370000	0.630000	0.000000	0.000000	0.922633	0.077367	360.995

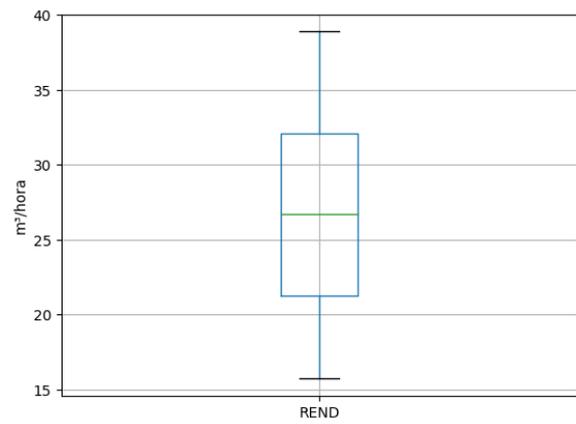
Fonte: Elaborado pelo autor.

Uma vez importados os dados no ambiente do Google Colab, foi conduzida uma análise para identificar a presença de valores discrepantes na variável de rendimento, os quais poderiam influenciar de forma adversa os resultados do modelo de rede neural. Esses valores atípicos foram tratados com base em critérios estatísticos, utilizando o método de detecção de *outliers* proposto por Seo (2006).

Os *outliers* foram identificados e ajustados considerando um intervalo de confiança de um desvio padrão acima e abaixo da média da variável de saída REND. Essa abordagem visa mitigar potenciais distorções nos resultados da análise. A Figura 9a mostra os dados sem o tratamento dos *outliers*, enquanto a Figura 9b mostra os dados pós-tratamento.



(a) Dados com valores atípicos



(b) Dados pós-retirada dos valores atípicos

Outra etapa de processamento dos dados se deu no processo de conversão das variáveis categóricas em representações numéricas adequadas para alimentar a RNA. Empregou-se a técnica de codificação One-hot utilizando a biblioteca Scikit-learn<sup>13</sup> codificada em Python. Essa etapa visa transformar os dados categóricos em vetores binários, sendo que, cada categoria é representada por uma sequência de zeros e uns, indicando sua presença ou ausência.

Este ajuste nos dados é importante para que a RNA possa processar eficientemente os dados de entrada, garantindo uma adequada representação das variáveis categóricas no contexto do modelo de aprendizado de máquina. Os Quadros 2 e 3 mostram as alterações na base de dados, antes e depois do tratamento das variáveis categóricas, respectivamente.

A etapa seguinte da pesquisa consistiu em avaliar a relação entre as variáveis de entrada e a variável de saída, por meio do cálculo correlação de Pearson, uma medida estatística que quantifica o grau e a direção da associação linear entre duas variáveis. A Equação (4.1) mostra como é feito o cálculo do índice de correlação de Pearson, onde  $n$  é o número de observações,  $x$  é a variável independente e  $y$  é a variável dependente.

$$r = \frac{n \sum xy - \sum x \sum y}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum y^2 - (\sum y)^2]}} \quad (4.1)$$

<sup>13</sup> Biblioteca de código aberto comumente utilizada como ferramenta de processamento de dados. Disponível em: <<https://scikit-learn.org/stable/>>. Acesso em: 02 mai. 2024.

Quadro 2 – Dados com variáveis categóricas

Variável	Tipo
FRENTE_AJUS	object
MANEJO	object
PRODUTO	object
COMP	float64
VMI_ARRED	float64
REND	float64
PD_1_POND	float64
PD_2_POND	float64
GW_1_POND	float64
GW_2_POND	float64
PERC_PD_POND	float64
PERC_GW_POND	float64
VCCC	int64

Quadro 3 – Dados pós-alteração para representação numérica

Variável	Tipo
FRENTE_AJUS_GN	int64
FRENTE_AJUS_CO	int64
FRENTE_AJUS_RD	int64
FRENTE_AJUS_PI	int64
FRENTE_AJUS_SB	int64
MANEJO_GW	int64
MANEJO_PD	int64
PRODUTO_SC	int64
PRODUTO_CC	int64
COMP	float64
VMI_ARRED	float64
REND	float64
PD_1_POND	float64
PD_2_POND	float64
GW_1_POND	float64
GW_2_POND	float64
PERC_PD_POND	float64
PERC_GW_POND	float64
VCCC	int64

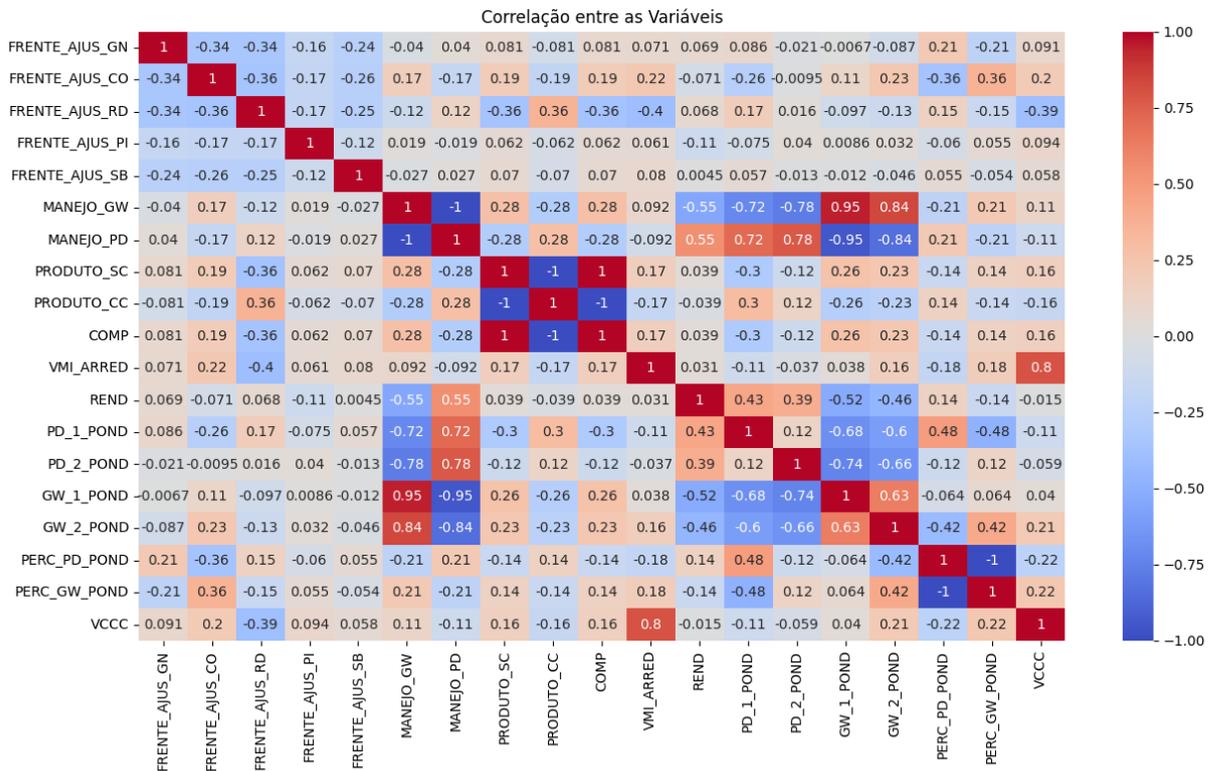
O estudo conduzido por [Araújo, Dos Santos e Gomes \(2019\)](#) fornece ideias adicionais sobre o desenvolvimento de código em Python para a geração de matrizes de correlação de Pearson, destacando a importância dessa técnica em diversas áreas de pesquisa e aplicação. Para este estudo, a correlação entre as variáveis foi levantada utilizando as funcionalidades disponíveis no pacote Pandas do Python.

A Figura 10 mostra um mapa de calor que indica o grau de correlação entre as variáveis do estudo. Conforme descrito na literatura ([MALINOVSKI; MALINOVSKI; MALINOVSKI, 2006](#)), é possível notar a forte correlação das variáveis relacionadas à declividade com o rendimento (REND), em metros cúbicos por hora.

Uma vez analisadas e estudadas as relações entre as variáveis, a etapa seguinte consiste na separação da base de dados em um grupo para teste e outro para treino. Nesta etapa foi utilizada a ferramenta `train_test_split` da biblioteca Scikit-learn, dividindo os dados na proporção de 70% para treinamento e 30% para teste (70/30) ou, de forma alternativa, 80% para treinamento e 20% para teste (80/20).

Essa abordagem é comumente adotada para garantir uma divisão adequada dos dados, permitindo que o modelo seja treinado em uma parte dos dados e avaliado em outra, conforme recomendado por [Géron \(2022\)](#). Trata-se de uma etapa fundamental para avaliar o desempenho do modelo de forma confiável e garantir que ele generalize bem para novos dados ([GÉRON, 2022](#)).

Figura 10 – Mapa de calor das correlações entre variáveis



Fonte: Elaborado pelo autor.

Em uma etapa posterior, os dados foram normalizados por meio da aplicação do StandardScaler, uma ferramenta presente no pacote Scikit-learn. Esse processo ajusta os dados para possuírem uma variância unitária, o que se revela benéfico em algoritmos de aprendizado de máquina que pressupõem a uniformidade de escala dos dados. Na sequência, deu-se início ao processo de definição dos hiperparâmetros da rede neural, por meio do uso da biblioteca Keras.

Nesta etapa, inicialmente, o modelo é definido como sequencial e uma camada de achatamento (Flatten) é adicionada para converter os dados de entrada em um formato apropriado para a rede neural. Em seguida, um *loop* é utilizado para adicionar camadas densas à rede, cujo número é determinado pelo hiperparâmetro *layers*. Para cada camada, são ajustados dois hiperparâmetros: *i*) o número de unidades (*units*), que controla a complexidade da camada; e *ii*) a função de ativação (*activation*), que define como as saídas da camada são transformadas.

Além disso, outro hiperparâmetro, *dropout*, é utilizado para determinar se uma camada de *dropout* será adicionada após cada camada densa, auxiliando na prevenção de *overfitting*. Em seguida, uma camada densa final com 10 unidades e ativação linear é adicionada, seguida pela compilação do modelo. O Quadro 4 destaca quais foram os hiperparâmetros calibrados e sua descrição.

Em adição, o otimizador Adam foi utilizado, com a taxa de aprendizado definida como um hiperparâmetro *lr* para ajuste, sendo que função de perda foi definida a partir do cálculo

Quadro 4 – Hiperparâmetros da rede neural que foram calibrados

Hiperparâmetro	Descrição
<i>layers</i>	Representa o número de camadas na rede neural, podendo variar de 1 a 5, com um incremento de 1, e a amostragem é linear.
<i>units</i>	Determina o número de unidades em cada camada da rede. Ele varia de 4 a 100, com um incremento de 12, e a amostragem também é linear.
<i>activation</i>	Define a função de ativação em cada camada da rede. As opções incluem <i>relu</i> , <i>linear</i> , <i>sigmoid</i> , <i>softmax</i> e <i>tanh</i> .
<i>dropout</i>	Indica se a regularização de dropout será aplicada em cada camada da rede. Ele pode ser verdadeiro ( <i>true</i> ) ou falso ( <i>false</i> ).
<i>lr</i>	Representa a taxa de aprendizado do otimizador. Varia de 0,0001 a 0,01, com amostragem logarítmica.

do erro quadrático médio (MSE), e a métrica de avaliação definida pelo erro absoluto médio (MAE). As Equações (4.2) e (4.3) mostram como é feito o cálculo dos erros MSE e MAE, respectivamente, sendo que  $n$  representa o número total de amostras,  $y_i$  é o valor verdadeiro da amostra  $i$ , e  $\hat{y}_i$  é o valor previsto pela modelo para a amostra  $i$ .

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.3)$$

Por fim, o sintonizador (*tuner*) foi utilizado para realizar uma pesquisa aleatória (*Random-Search*) dos hiperparâmetros. Os parâmetros do sintonizador incluem o modelo de hiperparâmetro a ser sintonizado (*hypermodel*), no caso, a função `build_model`, que define a arquitetura da rede neural. O objetivo da sintonização é minimizar a métrica `val_mae` (MAE dos dados de validação). O número máximo de tentativas é definido como 50 (`max_trials`), e cada tentativa é avaliada cinco vezes (`executions_per_trial`) para reduzir a variância nos resultados.

## 5 Resultados e discussão

Os resultados dos testes computacionais vinculado à rede neural MLP proposta foram avaliados considerando duas diferentes proporções de separação entre os conjuntos de treinamento e teste: **70/30** e **80/20**. A Tabela 1 apresenta as características dos hiperparâmetros, dos modelos que apresentaram os menores MAEs, entre as configurações avaliadas, para cada um dos conjuntos de proporções de treinamento e teste.

Tabela 1 – Melhores configurações para a rede MLP para os dois conjuntos de proporções de treinamento e teste, 70/30 e 80/20, considerando os menores valores de MAE.

Hiperparâmetros	70/30	80/20
layers:	1	1
units0:	40	88
activation0:	sigmoid	tanh
dropout0:	True	True
lr:	0.003058416102128597	0.007495525738071676
units1:	28	100
activation1:	relu	linear
dropout1:	True	True
units2:	16	52
activation2:	sigmoid	relu
dropout2:	True	False
units3:	64	64
activation3:	linear	relu
dropout3:	False	False
units4:	40	4
activation4:	sigmoid	linear
dropout4:	False	True
Score:	4.182762527465821	<b>4.03122911453247</b>

Pela Tabela 1 é possível observar que o modelo com a divisão de 80% para treinamento e 20% para teste apresentou uma menor perda na predição, conforme demonstrado pelo MAE. De forma complementar, a Tabela 2 mostra os cinco melhores resultados (menores MAEs) obtidos pelo sintonizador (*KerasTuner*), que é responsável por ajustar os hiperparâmetros da rede neural durante o processo de treinamento.

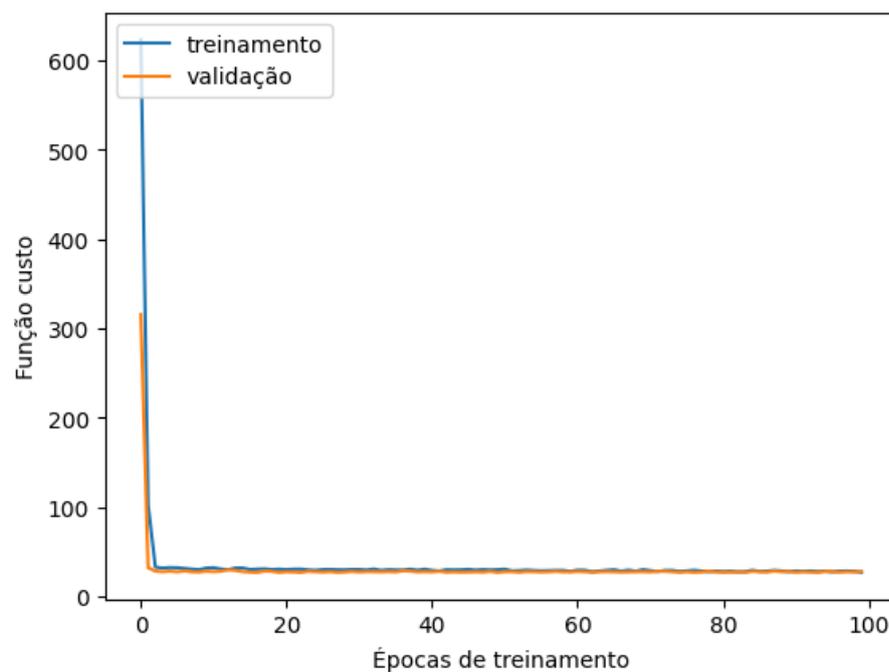
Em se tratando da função de custo, avaliada por meio do MSE, obteve-se um valor de 27,05. Essa métrica quantifica a média dos quadrados das diferenças entre os valores previstos pela rede neural e os valores reais dos dados de teste. Um MSE baixo indica uma melhor capacidade de previsão e um bom ajuste aos dados do modelo. O valor obtido sugere que a rede neural pode se beneficiar de ajustes adicionais para melhorar sua capacidade preditiva, seja pela introdução de novas variáveis de entrada ou outras configurações da rede, por exemplo, visando reduzir o erro nas previsões.

Tabela 2 – Cinco melhores resultados dos hiperparâmetros com treino e teste na proporção 80/20

Hiperparâmetros	1	2	3	4	5
layers:	1	2	4	4	1
units0:	88	100	40	28	76
activation0:	tanh	sigmoid	relu	softmax	relu
dropout0:	True	True	False	True	True
lr:	0.007495	0.004619	0.007327	0.009752	0.001503
units1:	100	4	4	88	88
activation1:	linear	relu	tanh	relu	softmax
dropout1:	True	False	False	True	True
units2:	52	16	100	40	64
activation2:	relu	sigmoid	softmax	softmax	linear
dropout2:	False	False	False	True	True
units3:	64	64	100	40	4
activation3:	relu	sigmoid	sigmoid	linear	linear
dropout3:	False	True	True	False	False
units4:	4	4	52	100	28
activation4:	linear	softmax	linear	linear	linear
dropout4:	True	False	False	True	True
Score:	<b>4.031229</b>	4.072879	4.094774	4.133914	4.153422

No tocante à velocidade de aprendizagem do modelo com melhor desempenho, o gráfico da Figura 11 demonstra uma progressão consistente do desempenho da rede MLP, à medida que são transcorridas as épocas de treinamento e validação. Esse comportamento sugere que o modelo está aprendendo efetivamente e se adaptando aos dados fornecidos, logo nas primeiras épocas.

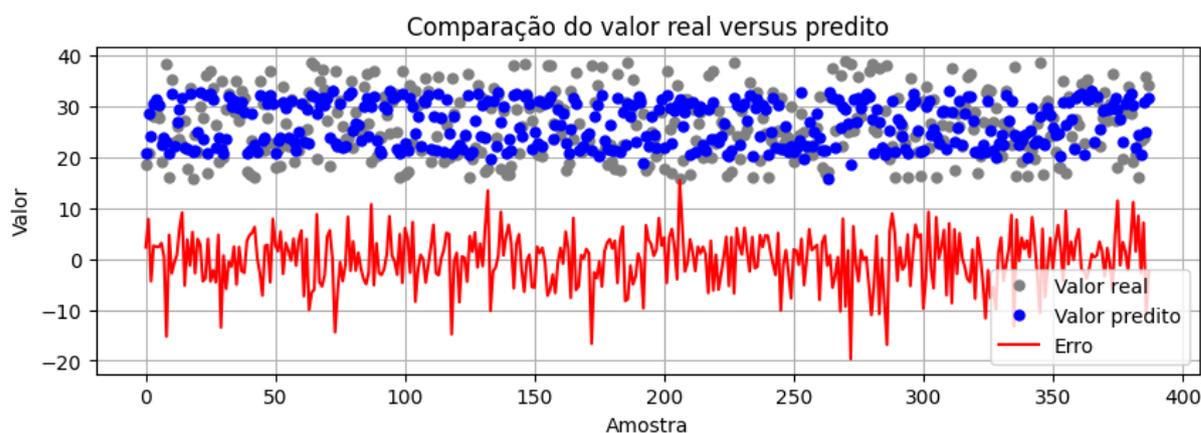
Figura 11 – Gráfico do histórico de treinamento da rede MLP número 1 da Tabela 2



Fonte: Elaborado pelo autor.

De forma complementar, o gráfico da Figura 12 apresenta uma análise comparativa entre os valores reais e as previsões geradas pela rede MLP número 1 da Tabela 2. É possível observar que, em comparação com os dados reais, a rede apresentou um desempenho mais acurado em torno da faixa central dos dados. Por outro lado, a rede encontrou dificuldade em prever situações mais próximas aos limites superiores e inferiores dos dados reais.

Figura 12 – Gráfico comparativo valores reais × valores preditos



Fonte: Elaborado pelo autor.

Neste contexto, pode-se dizer que o comportamento dos dados preditos, apresentados na Figura 12, sugerem que a rede pode estar enfrentando dificuldades em capturar e generalizar alguns padrões vinculados ao problema, em especial, àqueles que influenciam na obtenção de saídas mais próximas às regiões mais distantes da distribuição dos dados.

Ademais, acredita-se que os erros com maior variância observados no gráfico da Figura 12 são atribuídos a um processo de término de operação. Durante esse processo são necessários ajustes do volume ( $m^3$ ), registrado pelos operadores, para alinhá-lo com o volume disponibilizado no sistema, conforme determinado pelo levantamento do inventário pré-corte. Assim, este desvio ocorre devido à discrepância entre os dados operacionais iniciais e os valores efetivos do inventário, obtidos após a conclusão das atividades de corte e baldeio.

Em suma, a rede neural, em sua melhor configuração, resultou em um MAE de **4,03**, o que representa um percentual de erro de aproximadamente **17%** em relação aos valores reais. Por outro lado, a rede proposta revela uma melhoria substancial em comparação com os resultados obtidos pela abordagem convencional empregada atualmente pela empresa para a previsão da curva de produtividade. No contexto real, nos anos de 2022 e 2023, obteve-se, na prática, um MAE de 7,04, o correspondente a um percentual de erro de 30%.

Essa diminuição no erro em relação à metodologia adotada atualmente pela empresa sugere que a rede neural conseguiu capturar, com maior precisão, os padrões subjacentes dos dados de treinamento, resultando em previsões mais acuradas e confiáveis. Essa melhoria na precisão das previsões pode ter importantes implicações práticas para a empresa, permitindo, futuramente, uma gestão mais eficaz dos recursos e melhores tomadas de decisão em relação à produção florestal.

Por fim, após treinada a rede MLP com uma base de dados de 2022 e 2023, ela submetida a um teste de generalização utilizando uma base de dados distinta, composta por informações de 2021 e 2024. Os resultados obtidos revelaram uma MAE de **4,92**, com um erro percentual de **18%**, indicando uma capacidade consistente de generalização da rede neural, para além da base de dados de treinamento original. Esse desempenho indica uma eficácia do modelo desenvolvido, evidenciando sua capacidade de capturar padrões e relacionamentos relevantes nos dados operacionais, mesmo em contextos distintos.

## 6 Considerações Finais

Este estudo foi conduzido com o propósito de aprimorar a capacidade preditiva da produtividade, em metros cúbicos por hora ( $m^3/h$ ), na atividade de colheita florestal de uma empresa produtora de celulose, visando aperfeiçoar os dados de entrada utilizados em simulador operacional adotado pela organização. A partir de uma análise dos indicadores operacionais, estabeleceu-se como objetivo o desenvolvimento e calibração de modelos de redes neurais artificiais (RNAs) destinados a prever a produtividade das máquinas de colheita.

A metodologia empregada neste estudo compreendeu a coleta e preparação dos dados operacionais, seguida pela construção e ajuste de modelos de redes neurais do tipo *Multi-layer Perceptron* (MLP), os quais foram submetidos a um processo de seleção de hiperparâmetros com base no desempenho estatístico das saídas dos modelos. A avaliação do desempenho dos modelos desenvolvidos foi conduzida utilizando métricas o erro médio absoluto (MAE) e o erro quadrático médio (MSE).

Os resultados obtidos demonstraram uma melhoria na capacidade de previsão da produtividade em relação à metodologia atual da empresa, quando avaliado o MAE. A melhor configuração de rede MLP proposta resultou em um MAE de 4,03, o que representa uma diminuição de 13% no erro em comparação com os métodos atualmente empregados pela empresa. Além disso, a análise dos gráficos de treinamento e validação da rede indicou uma boa convergência e ajuste aos dados, destacando a eficácia do modelo na previsão da produtividade na colheita florestal.

Considerando os resultados deste trabalho, acredita-se a utilização da rede neural proposta possa proporcionar, no futuro, uma previsão mais acurada dos volumes de madeira colhida, permitindo um planejamento mais eficiente e preciso das operações do processo de planejamento operacional da empresa. Essa melhoria no processo de previsão tende a refletir em menores custos com movimentação de máquinas, uma vez que a alocação e deslocamento dos equipamentos podem ser otimizados de acordo com as previsões ajustadas. Acredita-se também que a melhoria no processo de previsão permita aprimorar alocação dos recursos, bem como uma melhor gestão de estoque de madeira, possibilitando uma melhor coordenação entre a produção e a demanda, minimizando excessos ou faltas de estoque.

Para estudos futuros, sugere-se a investigação de diferentes arquiteturas de redes neurais, bem como a aplicação de outras técnicas de pré-processamento de dados e estratégias mais refinadas de ajuste de hiperparâmetros. Sugere-se também a inclusão de outros fatores (variáveis de entrada) que possam influenciar na produtividade, enriquecendo a base de dados da rede e potencializando ainda mais os resultados preditivos.

Por fim, pode-se dizer que a metodologia adotada neste estudo apresenta potencial para ser estendida à predição de outros indicadores de produção, conforme abordado ao longo deste trabalho. Considerando a complexidade e interdependência dos diferentes aspectos operacionais na colheita florestal, acredita-se que a aplicação da mesma abordagem para a previsão de outros parâmetros de interesse possa contribuir para a melhoria dos processos de gestão florestal.

# Referências

- ARAÚJO, J. V. G. A.; DOS SANTOS, M.; GOMES, C. F. S. Desenvolvimento de um código em python para geração de matrizes de correlação de Pearson com laços a partir de “n” variáveis tomadas duas a duas. In: Anais do XIX Simpósio de Pesquisa Operacional e Logística da Marinha, 2019, Rio de Janeiro - RJ. **Anais eletrônicos** [...]. Rio de Janeiro, RJ: Blucher, 2019. v. 3, n. 1, p. 1–10. Disponível em: <<https://pdf.blucher.com.br/marineengineeringproceedings/spolm2019/080.pdf>>. Acesso em: 15 abr. 2024.
- BAGGIO, A. J.; STOEHR, G. W. D. Resultados preliminares de um levantamento dos sistemas de exploração usados em florestas implantadas de coníferas no sul do Brasil. **Floresta**, v. 9, n. 2, 1978. ISSN 1982-4688. Disponível em: <<http://dx.doi.org/10.5380/ufpr.v9i2.6219>>. Acesso em: 15 abr. 2024.
- BINOTI, D. H. B.; LEITE, H. G.; DE ANDRADE, V. C. L.; DA CONCEIÇÃO, M.; DE BARROS FILHO, N. F.; PIRES, L. M.; PINTO, L. O. R.; PAES, T. F. A. Importância relativa das variáveis preditoras no processo de modelagem da produtividade florestal. **Advances in Forestry Science**, Cuiabá, v. 9, n. 4, p. 1867–1873, 2022. Disponível em: <<https://doi.org/10.34062/afs.v9i4.13519>>. Acesso em: 25 abr. 2024.
- BORBA, M. d. C. **Predição para o uso da inteligência artificial no agronegócio na Caatinga**. 142 p. Tese (Doutorado em Agronegócios) — Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, 2022. Disponível em: <<https://lume.ufrgs.br/handle/10183/245283>>. Acesso em: 25 abr. 2024.
- BRAMUCCI, M.; SEIXAS, F. Determinação e quantificação de fatores de influência sobre a produtividade de “harvesters” na colheita de madeira. **Scientia Forestalis**, v. 30, n. 62, p. 62–74, 2002. Disponível em: <<https://www.ipef.br/publicacoes/scientia/nr62/cap06.pdf>>. Acesso em: 15 abr. 2024.
- CAUCHICK-MIGUEL, P. A.; FLEURY, A.; MELLO, C. H. P.; NAKANO, D. N. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 3. ed. Rio de Janeiro: Elsevier, 2018. 244 p. ISBN 9788535291346.
- CONWAY, S. **Logging practices: Principles of timber harvesting systems**. San Francisco: Miller Freeman Publications, Inc., 1976. 416 p. ISBN 0879300388.
- DE MIRANDA, A. **Comparação de máquinas para corte florestal no sistema Cut-To-Lenght na região de Sengés-PR**. 33 p. Monografia (Especialização em Gestão Florestal) — Universidade Federal do Paraná, Curitiba, MG, 2016. Disponível em: <<https://acervodigital.ufpr.br/xmlui/handle/1884/52395>>. Acesso em: 22 abr. 2024.
- DE SOUZA, M. C. **Avaliação da extração de madeira de eucalipto com o forwarder em áreas declivosas**. 70 p. Dissertação (Mestrado em Ciência Florestal) — Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, MG, 2013. Disponível em: <<http://acervo.ufvjm.edu.br/jspui/handle/1/352>>. Acesso em: 15 abr. 2024.

- FIORIN, D. V.; MARTINS, F. R.; SCHUCH, N. J.; PEREIRA, E. B. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, SciELO Brasil, v. 33, n. 1, p. 1309–1–1309–20, 2011. Disponível em: <<https://doi.org/10.1590/S1806-11172011000100009>>. Acesso em: 02 mai. 2024.
- FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. d. M. Redes neurais artificiais: Princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 7, n. 15, p. 47–57, 2016. ISSN 2175-1846. Disponível em: <<https://doi.org/10.3895/recit.v7.n15.4330>>. Acesso em: 25 abr. 2024.
- FLEURY, M. T. L.; WERLANG, S. R. d. C. Pesquisa aplicada: conceitos e abordagens. In: **Anuário de Pesquisa GVPesquisa 2016-2017**. FGV EAESP, 2017. p. 10–15. Disponível em: <<https://periodicos.fgv.br/apgvpesquisa/article/view/72796>>. Acesso em: 16 abr. 2024.
- FLÓREZ, C. A. C. **Proposta metodológica de otimização baseada em IA, ciência de dados e indústria 4.0. estudo de casos: serviços de emergência em e-hospital e sistema de gerenciamento de energias híbridas**. 341 p. Tese (Doutorado em Engenharia Mecânica) — Universidade Estadual de Campinas, Campinas, SP, 2020. Disponível em: <<https://doi.org/10.47749/T/UNICAMP.2020.1149374>>. Acesso em: 25 abr. 2024.
- GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems**. Sebastopol, CA: O'Reilly Media, 2022. 861 p. ISBN 9781098125974.
- GONÇALVES, S. B. **Modelagem matemática da produtividade do corte florestal mecanizado**. 62 p. Tese (Doutorado em Ciências Florestais) — Universidade Federal do Espírito Santo, Jerônimo Monteiro, ES, 2017. Disponível em: <<http://repositorio.ufes.br/handle/10/7710>>. Acesso em: 03 fev. 2024.
- LACERDA, L. C.; DA VITÓRIA, E. L.; FIEDLER, N. C.; DO CARMO, F. C. d. A.; GONÇALVES, S. B.; RAMALHO, A. H. C.; DE SOUZA ALVES, D. Prediction of mechanical availability in mechanized eucalyptus forest harvesting using artificial neural networks. **Journal of Agricultural Science**, v. 14, n. 3, 2022. ISSN 1916-9760. Disponível em: <<https://doi.org/10.5539/jas.v14n3p157>>. Acesso em: 15 abr. 2024.
- LINHARES, M.; SETTE JÚNIOR, C. R.; CAMPOS, F.; YAMAJI, F. M. Eficiência e desempenho operacional de máquinas harvester e forwarder na colheita florestal. **Pesquisa Agropecuária Tropical**, SciELO Brasil, Goiânia, v. 42, n. 2, p. 212–219, 2012. ISSN 1983-4063. Disponível em: <<https://doi.org/10.1590/S1983-40632012000200007>>. Acesso em: 15 abr. 2024.
- LOPES, E. S.; OLIVEIRA, F. M.; ROZA, B. L. Efeito de variáveis operacionais na produtividade de um harvester de pneus no desbastes de Pinus. **Floresta**, v. 47, n. 4, 2017. ISSN 1982-4688. Disponível em: <<http://dx.doi.org/10.5380/RF.V47I4.51112>>. Acesso em: 15 abr. 2024.
- LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos Avançados**, SciELO Brasil, v. 35, n. 101, p. 85–94, 2021. Disponível em: <<https://doi.org/10.1590/s0103-4014.2021.35101.007>>. Acesso em: 25 abr. 2024.
- MACHADO, C. C. (Ed.). **Colheita Florestal**. 3. ed. Viçosa, MG: Editora UFV, 2014. 543 p. ISBN 9788572694919.

MALINOVSKI, R. A.; MALINOVSKI, R. A.; MALINOVSKI, J. R. Análise das variáveis de influência na produtividade das máquinas de colheita de madeira em função das características físicas do terreno, do povoamento e do planejamento operacional florestal. **Floresta**, v. 36, n. 2, 2006. ISSN 1982-4688. Disponível em: <<http://dx.doi.org/10.5380/rf.v36i2.6459>>. Acesso em: 03 fev. 2024.

MARTINS, R. J.; SEIXAS, F.; STAPE, J. L. Avaliação técnica e econômica de um harvester trabalhando em diferentes condições de espaçamento e arranjo de plantio em povoamento de eucalipto. **Scientia Forestalis**, Piracicaba, v. 37, n. 83, p. 253–263, 2009. Disponível em: <<https://www.ipef.br/publicacoes/scientia/nr83/cap04.pdf>>. Acesso em: 03 fev. 2024.

MINETTE, L. J.; DA SILVA, E. N.; MIRANDA, G. de M.; DE SOUZA, A. P.; FIEDLER, N. C. Avaliação técnica da operação de extração de eucalyptus spp. utilizando o trator autocarregável e o trator florestal transportador “forwarder” na região sul da Bahia. **Engenharia na Agricultura**, Viçosa, MG, v. 16, n. 3, 2008. Disponível em: <<https://periodicos.ufv.br/reveng/article/view/27>>. Acesso em: 03 fev. 2024.

SANTOS, D. E. C. **Regressão e deep learning aplicados em modelagem de árvore individual para eucalipto**. 44 p. Dissertação (Mestrado em Ciências) — Universidade Federal de Viçosa, Viçosa, MG, 2021. Disponível em: <<https://locus.ufv.br/handle/123456789/28632>>. Acesso em: 25 abr. 2024.

SEO, S. **A review and comparison of methods for detecting outliers in univariate data sets**. 59 p. Dissertação (Master of Science) — University of Pittsburgh, Pittsburgh, 2006. Disponível em: <<http://d-scholarship.pitt.edu/7948/1/Seo.pdf>>. Acesso em: 15 abr. 2024.

SILVA, A. A. **Desenvolvimento do indicador de eficiência global de máquinas de colheita florestal (EGMF)**. 119 p. Dissertação (Mestrado em Ciências) — Universidade Federal de Viçosa, Viçosa, MG, 2017. Disponível em: <<https://locus.ufv.br/handle/123456789/25529>>. Acesso em: 16 abr. 2024.

SILVA, A. A. **Tecnologias digitais aplicadas na gestão do corte florestal com harvester**. 81 p. Tese (Doutorado em Ciências) — Universidade Federal de Viçosa, Viçosa, MG, 2021. Disponível em: <<https://www.locus.ufv.br/handle/123456789/28668>>. Acesso em: 15 abr. 2024.

SILVA, F. **Aplicação de redes neurais artificiais para estimar a produtividade do forwarder na extração de madeira**. 63 p. Dissertação (Mestrado em Ciências) — Universidade Federal de Viçosa, Viçosa, MG, 2015. Disponível em: <<https://www.locus.ufv.br/handle/123456789/6953>>. Acesso em: 15 abr. 2024.

SILVA, G. C. C. **Uso de redes neurais artificiais na predição de parâmetros e calibração do modelo 3-PG**. 202 p. Tese (Doutorado em Ciências) — Universidade Federal de Viçosa, Viçosa, MG, 2021. Disponível em: <<https://locus.ufv.br/handle/123456789/29703>>. Acesso em: 25 abr. 2024.

SIMÕES, D.; FENNER, P. T. Influência do relevo na produtividade e custos do harvester. **Scientia Forestalis**, Piracicaba, v. 38, n. 85, p. 107–114, 2010. Disponível em: <<https://www.ipef.br/publicacoes/scientia/nr85/cap10.pdf>>. Acesso em: 15 fev. 2024.

SIMÕES, D.; FENNER, P. T.; ESPERANCINI, M. S. T. Avaliação técnica e econômica da colheita de florestas de eucalipto com harvester. **Scientia Forestalis**, Piracicaba, v. 38, n. 88, p. 611–118, 2010. Disponível em: <<https://www.ipef.br/publicacoes/scientia/nr88/cap07.pdf>>. Acesso em: 03 fev. 2024.

SIQUEIRA, F. M. F. **Estratégia de otimização de processos com o uso de redes neurais artificiais**. 206 p. Dissertação (Mestrado em Engenharia Química) — Universidade Federal Fluminense, Niteroi, RJ, 2021. Disponível em: <<https://app.uff.br/riuff/handle/1/22073>>. Acesso em: 25 abr. 2024.

TANAKA, O. P. Exploração e transporte da cultura do eucalipto. **Informe Agropecuário**, Belo Horizonte, v. 12, n. 141, p. 24–30, 1986.

WERNEBURG, M. A. P. **Planejamento em grandes empresas florestais no Brasil**. 95 p. Dissertação (Mestrado em Ciência Florestal) — Universidade Federal dos Vales do Jequitinhonha e Mucuri, Diamantina, MG, 2015. Disponível em: <<http://acervo.ufvjm.edu.br/jspui/handle/1/1045>>. Acesso em: 15 abr. 2024.